

ラフ集合を用いた分類とその適用

加島 智子¹, Sophia Lin², 石井 博昭¹, 和多田 淳三²

¹ 大阪大学大学院 情報科学研究科

² 早稲田大学大学院 情報生産システム研究科

本論文ではラフ集合によってデータの分類を行っている。細分された部分集合がより大きな決定集合に分類することができるかを識別する。ラフ集合の概念によって、データを自動的に分類するモデルを提案している。ここではデータ分類を効率的に実現することを目的とし、高齢化問題に本手法を応用している。近年、高齢化社会の問題に直面し、解決を模索している。そこで本論文では識別問題として、様々な都市が高齢化社会に分類されるか否かを議論している。

A Rough Set Approach to Classification and Its Application

Tomoko Kashima¹, Sophia Lin², Hiroaki Ishii¹, Junzo Watada²

¹ Graduate School of Engineering, Osaka University

² Graduate School of Information, Production and Systems, Waseda University

The objective of this paper is to realize a simple classification method in a rough set approach that distinguishes whether a subset can be classified in the target set or not. The algorithms of Rough Set will be used to analyze the data and in order to illustrate the method, we just use some artificial data in this paper. As its application, we discuss the aged society that should influences on policy making. The problem of aged society has become more and more severe all over the world. Almost all the countries have to face and solve this problem. In this problem the distinguish is done whether cities can be classified into an aged one or not.

1 はじめに

本論文ではラフ集合を用いてデータ分類を行う[1]。ラフ集合は有効なデータ分類手段であり、注目を集めている。そこでラフ集合を用いて国または都市が高齢化社会に含まれるか否かラフ集合によって決定する方法を検討する。

ラフ集合は、1980年代に Z.Pawlak によって数学的なアプローチとして、データを分析するため開発された。新しいデータ分析手法と

して、ラフ集合はすべての種類の不確実なデータ、矛盾したデータおよび不完全なデータに有効的である。また、ラフ集合は情報システムに有効な知識獲得ができる。このように他のデータ分類アプローチと比較して、ラフ集合は多くの長所がある。1980年代以来、ラフ集合はその数学的理論、アルゴリズム、それらを実問題に広く応用してきた。

特に現在は、ラフ集合の数学的理論とアルゴリズムが注目を集めている。数学的な理論の研

究は、演算子の構造、ラフ集合の空間、ラフ集合理論の拡張などがある。また、アルゴリズムに注目する研究には、ラフ集合理論の縮小アルゴリズム、決定ルール抽出のアルゴリズムなどがある[2-4]。

2 ラフ集合論理

ラフ集合は1982年に提唱された理論で、感性工学の分野で用いられてきた。我々が何か対象を識別しようとするとき、粗い記述は対象を十分に特定できないというデメリットがあり、一方、細かい記述は対象をより精密に特定するものの、本質が見極めにくくなりやすいという欠点を持っている。ラフ集合は対象の集合をうまく特定できる範囲で情報を粗くすることで、対象の集合の程よい記述を求めることが可能である。

3. モデル

本論文ではラフ集合のアルゴリズムにより、データを自動的に分類するモデルを提案している。このモデルではデータ分類の効率化を実現することを目的としている。つまり、もし多くのデータを持っているならば、いくつかの特徴によりそれらを分類することが可能となる。データを入力するだけで自動的に分類される。この方法により、特定のグループに含まれるか否か簡単に判別することが可能となる。

図1はラフ集合の定義を示している。図1の集合Xの内側部分は正領域、集合1から集合17までの集合Xに重なる部分は境界域であることを表している。図のように正領域は集合Xに完全に含まれている。しかし、集合16と集合17は集合Xに大部分が含まれており、また集合1と集合2は集合Xにあまり含まれていない。したがって、集合1から集合17のような境界域が集合Xに含まれているかどうか決

定する方法を考えていく。方法として、各集合に対してしきい値を持たせる。集合の要素がしきい値を越える場合、部分集合に含むまたは、含まないとする。

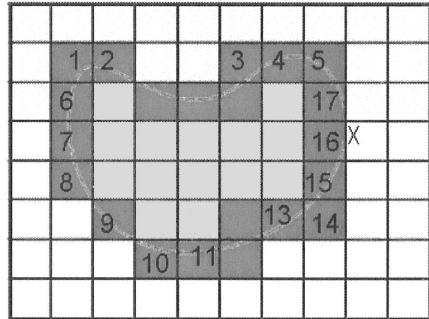


図1：ラフ集合のイメージ

上記の説明に従い、本論文では、モデルのアルゴリズム設計を行った。全体集合に含まれる30の部分集合があり、それぞれの部分集合は50の標本値を持っていると仮定する。さらに、全体集合の判別比があり、それは各部分集合の分類結果が判別比より大きい場合、その部分集合は集合Xに含むことができるとする。このモデルを用いることにより、分類問題の結果を容易にかつ迅速に得ることが可能となる。このモデルの設計手順はステップ3.1、3.2、3.3で述べる。

3.1 標準的な確率変数に対する値の生成

まず、各部分集合は正規分布に従うと仮定し、現実の状況と良く似たサンプルデータを作成する。次に集合Aは30の部分集合を持ち、各部分集合は50の標本値を持つとする。値はボックス＝ミュラー法（Box-Muller transform）により正規分布に従う値を生成する。まず(0,1)の一様乱数をボックス＝ミューラー法で変換し

A	B	C	D	E	F	G	H		
1	The number of samples.	Observation path.	SubSet1	SubSet2	SubSet3	SubSet4	SubSet5	SubSet6	SubSet7
2	50	0.5	79	69	68	75	67	65	66
3	Sample01		69.404	69.807	66.620	51.710	71.230	71.230	74.957
4	Sample02		64.510	61.940	67.370	61.730	60.040	70.620	54.690
5	Sample03		51.598	67.262	44.421	78.064	67.418	68.312	27.912
6	Sample04		65.715	79.443	72.255	109.001	73.715	74.476	72.467
7	Sample05		66.871	69.704	74.665	70.000	65.930	107.800	54.494
8	Sample06		67.625	73.557	61.336	66.169	71.114	64.494	54.494
9	Sample07		66.681	69.744	67.981	56.676	62.865	74.908	52.292
10	Sample08		56.497	49.125	67.708	66.490	71.769	68.840	65.836
11	Sample09		67.313	64.558	69.881	64.587	59.800	73.345	58.128
12	Sample10		65.510	67.708	66.490	66.490	66.490	66.490	66.490
13	Sample11		65.120	76.098	45.418	28.659	67.581	64.190	111.982
14	Sample12		71.815	64.839	62.208	65.459	63.446	76.021	29.903
15	Sample13		70.288	65.382	62.321	76.887	102.378	79.474	64.003
16	Sample14		64.041	64.041	64.041	64.041	64.041	64.041	64.041
17	Sample15		63.230	125.211	65.495	68.244	106.206	64.949	89.090
18	Sample16		41.459	73.001	60.915	66.662	40.959	107.587	37.544
19	Sample17		26.680	76.106	71.075	110.978	79.030	71.121	62.223
20	Sample18		60.617	60.617	60.617	60.617	60.617	60.617	60.617
21	Sample19		70.324	61.220	62.056	71.277	47.424	62.223	57.544
22	Sample20		61.768	76.384	61.309	59.095	61.291	76.894	65.772
23	Sample21		115.617	57.338	69.282	53.767	77.684	110.867	86.765
24	Sample22		86.074	67.700	60.664	66.208	97.000	68.140	72.692

図2：モデルイメージ



図3：モデルコードの例

て正規乱数をえることから始める。一様乱数(0,1]の要素 a と b を次の変換を用いて変換する。二つの相関のない c と d の正規乱数が次の式にて得られる。

$$c = \sqrt{-2 \ln a} * \cos(2\pi b) \quad (1)$$

$$d = \sqrt{-2 \ln a} * \sin(2\pi b) \quad (2)$$

本論文では数式(2)の方法を用いて乱数を発生させる。

3.2 サンプリング

各部分集合の生成後、各部分集合に対してしきい値を定める。しきい値は”threshold = Int(60 + 20 * Rnd0)”とする。しきい値よりも大きな値の場合は条件を満たしているとする。例えば、sample07 の数は 88.681 であり、しきい値は 79 なので条件を満たしている。そ

して、全てに対して条件を満たしているかどうか計算し、各部分集合に対しての満たしている比率を求める。もし、比率が判別比よりも大きい場合、部分集合は集合 A に含まれる。そうでなければ、集合 A に含むことはできない。このモデルでは判別比 0.5(50%)としている。

3.3 T-検定

サンプリングの後、サンプルの結果が全体の部分集合の結果と一致するかどうか Student's T 検定により確認を行う。この検定では片側検定を行う。使用する式は以下に記述する。

$$T = \frac{\bar{x} - \mu_0}{\frac{S_n^*}{\sqrt{n}}} \quad (3)$$

\bar{x} は各部分集合の平均とする。 μ_0 は各部分集合のしきい値とする。 S_n^* は各部分集合の修正された標本分散とする。また、 n は部分集合の値とする。ここでは有意水準は 5%とする。

検定は以下のように行う。最初に、各部分集合の平均を計算する。次に、修正済の標本分布と T を計算する。 λ はエクセルの”TINV”によって得ることができる。T 検定により、 $T \geq -\lambda$ ならばサンプルの結果を用いる。そして、もし $T \leq -\lambda$ ならばサンプリングを棄却し、サンプリングを続けなければならない。

3.4 シミュレーション

このセクションでは、高齢化社会のサンプルに対して、ラフ集合モデルを適用する。

はじめに、ある国に 30 都市があるとする。そして、各都市の 50 人の市民に対してサンプルを行う。全ての世代の市民に対してラフ集合モデルを適用する。モデルにデータ入力をし、データ分類のシミュレーションを行う。しきい値より大きいデータを数え、最後にどの都市が高齢化社会に含むことができるか否か得る。

例えば、50の都市のデータがあり、各都市では50人分の年齢データがある。まず、都市1のしきい値を62とする。その都市の62歳以上の市民の割合が判別比の0.5(50%)と比較して大きい場合、都市1は高齢化社会に入ったと判断する。私たちのモデルに適用し、評価を行う。最初に62よりも大きい値を数え、適合度と適合比率が38, 0.76と計算する。都市1の比率が0.76と判別比よりはるかに大きいため、第一段階として都市1はサンプル結果により高齢化社会に入ったといえる。しかし、その信頼度を確認するためにT検定を用いる。エクセルの結果によりT検定の結果を確認し、サンプリングの結果を受け入れる。そして、都市1は高齢化社会に直面していると言うことができる。

都市2から都市30まで同様に上記のアルゴリズムを繰り返すことにより都市1と同様に結果を得ることができる。最後に30の都市全ての結果を得ることができる。このセクションでは、サンプルの高齢化社会の状況にラフ集合モデルを適用している。まず、ある国に30都市があるとする。各都市の50人の市民に対してサンプルを行う。これは全ての世代の市民に対してラフ集合モデルを適用する。モデルにデータ入力をした後、データ分類のシミュレーションを行う。しきい値より大きいデータが数えられ、そして最後にどの都市が高齢化社会に含むことができるか否か得ることができる。

Sample45		79	49	82	65	53	51
Sample46		76	94	79	86	74	40
Sample47		56	61	68	66	56	80
Sample48		89	73	61	71	55	76
Sample49		64	59	69	66	92	81
Sample50		87	67	63	82	55	95
The value of goodness		38	35	25	24	29	16
The ratio of goodness		0.76	0.7	0.5	0.48	0.58	0.96
Is it included in A?	YES	YES	NO	NO	YES	NO	
T-Test							
average value of samples		69.61590253	60.88104	69.1652	70.49778	67.77911	67.74423
S _n		401.7886112	510.007	349.7981	401.0574	272.849	346.3568
T		3.123566407	3.349828	-0.97576	-1.82323	1.558637	-3.49195
λ		1.675905026					
accept or reject?	accept	accept	accept	reject	reject	accept	reject

図4：シミュレーション例

4 終わりに

本研究では現実の様々な問題に対するラフ集合理論を適用した分類方法を提供することを目的とした。また、本論文で提案したモデルではラフ集合を改良した。しかし、現実問題に適用するには多くの問題がある。例えば、現実にデータを集めることは困難である。また、T検定を行う段階で最初のサンプリングの結果が却下された場合、限りなくサンプリングを行う問題に直面する。したがって、そのような問題を克服するためにラフ集合を適用する更なる研究が必要である。また、ラフ集合を用いて、将来現実問題を解決するために設計を行うべきである。

参考文献

- [1] Pawlak, Zdzisław. "Rough Sets: Theoretical Aspects of Reasoning About Data. Dordrecht" Kluwer Academic Publishing. ISBN 0-7923-1472-7. (1991).
- [2] Ziarko, Wojciech. "Rough sets as a methodology for data mining". Rough Sets in Knowledge Discovery 1: Methodology and Applications: 554–576, Heidelberg: Physica-Verlag. (1998).
- [3] Ziarko, Wojciech; Shan, Ning. "Discovering attribute relationships, dependencies and rules by using rough sets". Proceedings of the 28th Annual Hawaii International Conference on System Sciences (HICSS'95): 293–299, (1995).
- [4] Chen degang, Zhang-wenxiu, "Rough Set and topology spaces, Journal of XianJiaotong University ,1313-1315.(2001).